

## Metode Deep Learning Pada Sistem Rekomendasi : Review Paper

Diana Ikasari, Adang Suhendra dan Nuke Farida {d\_ikasari, adang, nuke\_farida}@staff.gunadarma.ac.id  
Sistem Informasi, Teknologi Informasi, Ilmu Komunikasi, Universitas Gunadarma Jalan Margonda Raya  
100, Depok

### ABSTRAK

*Berkembangnya data online yang pesat saat ini, berdampak pada pencarian dan analisis konten dari suatu topik tertentu. Maka, diperlukan metode yang bisa mewakili bagaimana user mencari dan menganalisis informasi dari sejumlah data. User melakukan filter dan mencari Informasi dengan mengekstraksi fitur Informasi dalam domain tertentu, dan memetakan fitur untuk klasifikasi tertentu yang dicari. Tetapi sulit untuk mendefinisikan anotasi data besar secara manual, sehingga, data harus diubah menjadi fitur-fitur khusus, memetakannya ke dalam karakter domain informasi spesifik. Banyak penelitian telah dilakukan untuk menyediakan learning algoritma untuk mendapatkan hasil yang lebih akurat. Dalam proses pelatihan, dapat mempertimbangkan rekomendasi dari lingkungan untuk mencapai pengetahuan yang lebih akurat dan berarti untuk klasifikasi. Beberapa perkembangan revolusioner dari sistem rekomendasi menerapkan metode deep learning, yang telah dilaksanakan di banyak bidang seperti Voice Recognition, Image Processing dan Natural Language Processing. Pada penulisan ini, menjelaskan penggunaan metode deep learning dari penelitian terkait yang telah diterapkan di berbagai domain dan memberikan kontribusi hasil yang lebih baik. Penelitian ini diharapkan dapat membantu dalam mengeksplorasi algoritma deep learning untuk meningkatkan akurasi dari sistem rekomendasi*

**Kata Kunci :** Metode, Deep Learning, Learning Algoritma, Sistem Rekomendasi

### PENDAHULUAN

Sistem rekomendasi saat ini telah menjadi bagian penting dari industri, karena dapat digunakan untuk membantu menciptakan strategi promosi penjualan di banyak situs online dan aplikasi seluler. Sebagai contoh 60 persen video klik di YouTube berasal dari rekomendasi [1]. Saat ini banyak perusahaan menggunakan metode *deep learning* untuk meningkatkan kualitas rekomendasi [2,3,4]. Keberhasilan metode *deep learning* untuk rekomendasi, baik dalam sains dan industri, memerlukan tinjauan komprehensif dan kesimpulan yang kuat, agar peneliti dan praktisi dapat lebih memahami kekuatan dan kelemahan metode di masing-masing aplikasi dari sistem yang direkomendasikan.

Sistem Rekomendasi menggunakan pendapat pengguna tentang produk dan layanan dari domain atau kategori tertentu. Output dari sistem rekomendasi dapat membantu untuk membuat keputusan dalam pemilihan produk atau layanan, sehingga dapat membantu pelanggan untuk membuat keputusan berdasarkan informasi tentang produk yang dibeli. Sistem rekomendasi adalah suatu program yang melakukan prediksi suatu item, seperti rekomendasi film, musik, buku dan lain sebagainya

dengan memanfaatkan opini *user* sehingga dapat menarik *user* yang lainnya. Sistem ini berjalan dengan mengumpulkan data dari *user* secara langsung maupun tidak langsung [5]. Pengumpulan data secara langsung dapat dilakukan sebagai berikut :

- Meminta *user* untuk melakukan rating pada sebuah item.
- Meminta *user* untuk melakukan *ranking* pada item favorit setidaknya memilih satu item favorit.
- Memberikan beberapa pilihan item pada *user* dan memintanya memilih yang terbaik.
- Meminta *user* untuk membuat daftar item yang paling disukai atau item yang tidak disukainya.

Pengumpulan data dengan tidak langsung berhubungan dengan seorang *user*, dilakukan dengan cara seperti berikut:

- Mengamati item yang dilihat oleh seorang *user* pada sebuah web.
- Mengumpulkan data transaksi pada sebuah toko online

*Deep learning*, mempelajari berbagai tingkatan representasi dan abstraksi dari data, yang dapat menyelesaikan *supervised* dan

*unsupervised learning task*. *Deep learning* bisa diartikan sebagai rangkaian metode untuk melatih jaringan saraf buatan multi-lapisan (bertingkat).

Pengenalan representasi secara ekspresif dan diskriminatif pada *image* adalah hal yang penting, dan *deep learning* telah digunakan untuk mempelajari otomatisasi *learning* dalam hal representasi *image* tersebut, termasuk deteksi *image*, *recognition*, *classification* dan *retrieval*. Permasalahan ini telah banyak dipelajari dan banyak hasil karya yang telah di desain dan diadopsi dalam fungsi yang berbeda [6].

Sistem *speech recognition* dikembangkan dengan menggunakan *end to end deep learning*. Penggunaan system pelatihan RNN dan optimalisasi beberapa Graphic Processing Unit (GPU) membuat metode ini menjadi lebih sederhana bila dibandingkan dengan metode tradisional *speech recognition*. Pengenalan algoritma *deep learning* [7] telah memperbaiki kinerja *speech system*, biasanya dengan memperbaiki model akustik.

Bentuk representasi dari system rekomendasi terkait dengan pemrosesan teks adalah peringkat yang diberikan oleh *user*. Misalnya, dalam sistem rekomendasi film, faktor mendasar seperti genre, aktor, atau sutradara film dapat mempengaruhi perilaku pemeringkatan *user*. Teknik faktorisasi matriks tidak hanya menemukan faktor tersembunyi, tetapi juga mempelajari kepentingan masing-masing *user* dan bagaimana setiap item memenuhi setiap faktor. Salah satu pendekatan yang digunakan untuk mengatasi kekurangan pengalaman data ini adalah dengan menggunakan informasi dalam *review* teks. Dalam banyak sistem rekomendasi, *user* dapat menulis *review* untuk produk. *User* menjelaskan alasan di balik peringkat mereka dalam ulasan teks. Ulasan yang diberikan berisi informasi yang bisa digunakan untuk meringankan masalah *sparsity*. Salah satu kekurangan teknik *Collaborative Filtering* adalah memodelkan *user* dan item hanya berdasarkan peringkat numerik yang diberikan oleh *user* dan mengabaikan informasi yang ada pada *review* teks. Baru-baru ini, beberapa studi telah menunjukkan bahwa menggunakan

*review* teks dapat meningkatkan akurasi prediksi sistem rekomendasi, khususnya untuk *item* dan *user* dengan rating yang sedikit[9]. Diusulkan model berbasis *Neural Network* (NN) dengan nama *Deep Cooperatif Neural Network* (DeepCoNN), untuk menggambarkan *user* dan *item* secara bersama-sama menggunakan *review* teks untuk masalah prediksi rating.

## METODE PENELITIAN

Beberapa metode *deep learning* dapat diaplikasikan dalam beberapa domain. Dalam penelitian ini mencoba menjelaskan beberapa penelitian yang dikembangkan dalam domain *image processing*, *speech recognition* serta *text mining*.

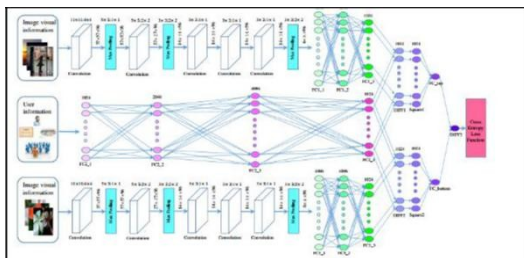
### *Image Recommendation.*

Representasi dari *image* sangat mewakili ekspresi suatu bentuk atau kejadian dibandingkan bila diuraikan dengan kata-kata, *image* menggambarkan sejuta makna. Semakin banyaknya koleksi gambar yang tersebar dalam media, mencari informasi akan *image* yang dapat memenuhi keingintahuan pengguna dari koleksi data *image* yang begitu besar semakin banyak dibutuhkan, penekanan pentingnya pencarian citra dan rekomendasi *image* yang digunakan sebagai filter bagi pengguna. Hal semacam itu tidaklah mudah karena adanya kesenjangan dalam memahami semantik dari *image* dianggap sebagai *gap* dalam memahami maksud atau preferensi *user* atas *image* tersebut. Dibandingkan dengan bentuk rekomendasi untuk data terstruktur, pencarian *image* dan rekomendasi memiliki lebih banyak tantangan karena gambar tidak memiliki representasi yang efektif.

Model *dual net deep network* dilakukan untuk membuat rekomendasi *image* kepada *user*. Jaringan terdiri atas 2 sub-network yang memetakan gambar dan preferensi pengguna kedalam ruang latent semantik yang sama. Dalam hal ini jaringan mampu mencapai representasi keduanya yaitu *image* dan *user*, yang disebut sebagai representasi *hybrid*. Representasi *hybrid* ini secara langsung dapat membandingkan untuk membuat keputusan dalam rekomendasi. Metode *Comparative Deep Learning* (CDL)

digunakan untuk menangani data training yang tidak sempurna. Disain dilakukan dengan *dual-net* pada *deep network*, dalam hal ini dua *sub-network* memetakan input *image* dan preferensi *user* kedalam ruang *latent semantic* yang sama, dan jarak diantara *user* dan *image* dalam ruang latent dihitung untuk membuat keputusan. Metode CDL digunakan untuk melatih *deep network* menggunakan sepasang *image* dibandingkan tiap *user* untuk mempelajari pola dari jarak relatif.

Arsitektur CDL terdiri atas 3 *sub-network*. Bagian paling atas dan bagian bawah *sub-network* adalah *two Convolutional Neural Networks* (CNNs) dengan konfigurasi identik dan parameter bersama, yang dirancang untuk menangkap informasi visual *image*. *Sub-network* yang ditengah adalah CNN yang di desain untuk informasi bagi *user*. Pada *top* atau *bottomsub-network* terdapat 5 *convolution layer*, 3 *max-poolinglayer* dan 3 *fully-connection layers*. Konfigurasi ini termasuk ukuran kernel konvolusi di lapisan konvolusi dan jumlah neuron pada lapisan koneksi penuh ditunjukkan pada Gambar 1.



**Gambar 1.** Deep Network dan Parameter untuk CDL

Pada gambar 1, ada tiga *sub-networks* yang semuanya menampilkan vektor 1024-dim sebagai representasi *image* dan *user*. Gambar pemrosesan *top* dan *bottomsub-network* identik. *Sub-network* tengah memproses pengguna. Setelah *sub-network* ini ada dua jaringan penghitung jarak. Perbedaan antara jarak dimasukkan ke fungsi *cross-entropy loss* akhir untuk perbandingan dengan label. Angka yang ditunjukkan di atas setiap panah memberi ukuran output yang sesuai. Angka yang ditunjukkan di atas setiap kotak

menunjukkan ukuran kernel dan ukuran langkah untuk lapisan yang sesuai.

### Speech Recognition

Sistem tradisional *speech* menggunakan banyak tahap pemrosesan yang direkayasa, termasuk fitur masukan khusus, model akustik, dan Model *Hidden Markov* (HMM). Untuk memperbaiki pipeline ini, domain *expert* harus menginvestasikan banyak upaya untuk menset fitur dan model. Sistem *speech recognition* tertinggi bergantung pada jaringan pipeline yang canggih yang terdiri dari beberapa algoritma dan tahapan pemrosesan *hand-engineered*. Dalam *deep learning* dikembangkan sebuah sistem *speech end-to-end*, yang disebut "*Deep Speech*", di mana *deep learning* menggantikan tahap pemrosesan *hand-engineered* ini. Dikombinasikan dengan model bahasa, pendekatan ini mencapai kinerja yang lebih tinggi daripada metode tradisional pada fungsi *speech recognition* dan juga menjadi lebih sederhana. Hasil ini dimungkinkan dengan melatih jaringan syaraf berulang yang besar *Recurrent Neural Network* (RNN) dengan menggunakan beberapa *Graphic Processing Unit* (GPU) dan ribuan data. Karena sistem ini belajar langsung dari data, sehingga tidak memerlukan komponen khusus untuk adaptasi speaker atau noise filtering. Sebenarnya, dalam pengaturan di mana ketangguhan terhadap variasi dan kebisingan speaker sangat penting, *Deep Speech* melebihi metode yang telah dipublikasikan sebelumnya menggunakan *Switchboard Hub5'00*, menghasilkan kesalahan 16,0%, dan melakukan yang lebih baik daripada sistem komersial dalam tes pengenalan suara yang berisik. Sistem *end to end deep learning* telah di implementasikan untuk *based speech system* yang menggunakan multi GPU training dengan cara mengumpulkan data dan membangun strategi sintesis untuk set pelatihan besar yang menunjukkan distorsi yang harus ditangani oleh sistem, seperti latar belakang noise dan efek lombart.

## Text Mining

Beberapa penelitian tentang deep learning yang berhubungan dengan teks dibahas pada penelitian ini. Dalam penelitian dengan judul *Deep Model to Learn Item Properties and User Behavior Jointly from Review Text* menggambarkan bahwa begitu banyak jumlah informasi yang ada pada review yang ditulis oleh user, yang dapat dijadikan sebagai sumber informasi namun diabaikan oleh hampir semua sistem rekomendasi yang ada saat ini, dimana hal ini dapat mengurangi masalah *sparsity* dan meningkatkan kualitas dari rekomendasi[10]. Dalam paper ini, menyajikan sebuah *deep learning* model yang mempelajari gabungan *item* properties dan perilaku user berdasarkan teks review, yaitu model *Deep Cooperative Neural Network (DeepCoNN)*, sebuah model yang terdiri atas dua pasangan paralel *neural network* pada layer terakhir. Satu *network* fokus mempelajari perilaku *user* dengan mengeksplorasi review yang ditulis oleh *user*, dan *network* yang lain mempelajari *item property* dari review yang ditulis untuk suatu *item*. *Shared layers* diperkenalkan di atas memungkinkan faktor latent dipelajari untuk *user* dan *item* agar berinteraksi satu sama lain dengan cara yang mirip dengan teknik mesin faktorisasi.

*DeepCoNN* adalah *deep* model pertama yang mewakili *user* dan *item* secara bersamaan menggunakan review. Model *DeepCoNN* memberikan kontribusi yaitu mampu mewakili review teks dengan menggunakan teknik penyisipan kata praprelatihan untuk mengekstrak informasi semantik dari review. Bentuk keuntungan yang signifikan dari model *DeepCoNN* jika dibandingkan dengan pendekatan model lain adalah mampu memodelkan *user* dan *item* secara bersamaan untuk memprediksi akurasi dengan tepat[8].

Pada penelitian dengan judul *Representation Learning of User and Items for Review Rating Prediction* menjelaskan bagaimana *deep learning* digunakan untuk memproses pengolah teks, dimana pada saat ini umumnya *website e-commerce* akan mendorong *user*-nya untuk menilai *item* yang dibeli serta menuliskan ulasannya [11]. Informasi akan review teks ini telah terbukti sangat berguna dalam memahami preferensi

dari *user* dan *item* properties, hal ini dapat meningkatkan kemampuan website untuk membuat rekomendasi personal. Pada paper ini, dijelaskan suatu model preferensi *user* dan properties *item* menggunakan *Convolution Neural Network (CNN) with attention (Attn+CNN)*, dimotivasi oleh kesuksesan besar fungsi CNN pada *natural language processing*. Dengan menggunakan gabungan review dari *user* dan *item*, dibangun vector representasi dari *user* dan *item* menggunakan *attention-based CNN*. Representasi dari vector ini akan digunakan untuk memprediksikan nilai peringkat bagi *user* pada suatu *item*. Dilakukan training jaringan *user* dan *item* secara bersama-sama, yang memungkinkan interaksi antara *user* dan *item*, dengan cara yang mirip teknik matriks faktorisasi. Bentuk visualisasi dari layer *attention* memberikan pemahaman kapan kata-kata dipilih oleh model yang diarahkan ke preferensi *user* atau *item* properti. Validasi model yang diusulkan pada populer review datasets, seperti *yelp* dan *amazon* kemudian membandingkan hasilnya dengan *matrix factorization (MF)* dan *hidden factor and tropical (HFT)*. Hasil

eksperimen menunjukkan peningkatan melalui HFT, yang membuktikan efektifitas dari representasi yang dipelajari dari *network* pada review teks untuk memprediksikan peringkat.

*Attn+CNN* digunakan untuk mempelajari representasi *user* dan *item* berdasarkan review korespondensi dari *user* dan *item*, representasi ini digunakan untuk memprediksi rating dari *user* pada *item*, sama seperti teknik MF. *Attention layer* digunakan sebelum CNN layer, berfungsi untuk memilih kata kunci dari *local window* yang berkontribusi pada peringkat. Visualisasi dari *attention layer* memberikan wawasan mengenai kata-kata yang dipilih oleh model yang menggambarkan preferensi *user* atau *item* properti

## Time Series Data Prediction

*Neural Network* menjadi sebuah solusi pilihan yang digunakan untuk memperkirakan nilai masa yang akan datang dari sebuah time-series data, misalnya prediksi nilai index tukar asing, prediksi nilai index stock pasar, dan lain-lain.

Beberapa hal yang terjadi dan merupakan sebuah masalah yang dialami berhubungan dengan *existing approach*, diantaranya adalah [12]:

Masalah *overfitting*: penyebab buruknya performa pada *machine learning* dikarenakan model yang sangat kompleks. Model dengan variasi yang banyak memiliki performance yang buruk dan akan menimbulkan reaksi berlebihan terhadap fluktuasi kecil pada proses data pelatihan.

Konfigurasi bobot awal: bobot nilai awal koneksi mempengaruhi proses training, menyerupai pemetaan nonlinier ruang input ke ruang keluaran. Bobot awal yang sesuai dapat mempercepat konvergensi pembelajaran dan menghindari proses belajar berhenti optimal di tingkat lokal.

*Optimization learning* parameter: Tingkat pembelajaran yang sesuai diperlukan selama pelatihan, hal ini mempengaruhi kecepatan proses pembelajaran, tingkat pembelajaran yang terlalu tinggi dapat menghasilkan konvergensi pembelajaran yang tidak stabil, dan tingkat pembelajaran yang kecil akan menolak proses pembelajaran.

Untuk mengatasi masalah yang ada diusulkan sebuah arsitektur dengan deep neural network yaitu *Deep Belief Network* (DBN) yang terdiri atas 3 (tiga) layer dengan *Particle Swarm Optimization* (PSO) untuk mengatasi dan mencari nilai optimal dari learning parameter, yaitu jumlah unit pada *visible* dan *hidden* layer serta learning rate. Jaringan DBN dioptimalkan menggunakan *Descen Probabilities* dari fungsi energi aktivasi[12]. Uji coba dilakukan dengan menggunakan dataset *Competition on Artificial Time Series* (CATS), melakukan perbandingan akurasi prediksi dari *short term* dan *long term* DBN dengan algoritma

*Multilayer Perceptron* (MLP) dan *Autoregressive Moving Average* (ARIMA), dengan perolehan hasil yang menggambarkan bahwa DBN memberikan hasil prediksi *short term* dan *long term* yang lebih baik dari MLP dan ARIMA diukur menggunakan *Lorenzt Chaos* serta menggunakan *Logistic map*.

## HASIL DAN PEMBAHASAN

Sistem rekomendasi menjadi sangat umum dalam beberapa tahun terakhir seiring dengan berkembangnya *online shopping*.

Perusahaan seperti Amazon mengembangkan sejumlah besar produk untuk memenuhi kebutuhan pelanggan yang berbeda-beda. Semakin banyak pilihan produk tersedia bagi pelanggan di era *e-commerce* semakin sulit juga bagi pelanggan untuk menentukan pilihan. Untuk bisa menemukan apa yang sebenarnya mereka butuhkan, pelanggan harus memproses sejumlah besar informasi yang diberikan oleh penyedia layanan *e-commerce*. Salah satu solusi untuk memudahkan masalah *overload informasi* ini adalah menggunakan sistem rekomendasi. Di satu sisi, sistem

rekomendasi tradisional akan merekomendasikan *item* berdasarkan kriteria yang berbeda, seperti preferensi pengguna atau profil pengguna sebelumnya. Di sisi lain, penggunaan teknik *deep learning* akan mencapai kinerja yang lebih menjanjikan di berbagai bidang, seperti *Computer Vision*, *Audio Recognition* dan *Natural Language Processing*. Namun,

aplikasi *deep learning* pada sistem rekomendasi belum dieksplorasi dengan baik. Beberapa teknik *deep learning* yang dikembangkan terkait dengan sistem rekomendasi dijelaskan pada bagian ini.

### Teknik-Teknik Dalam Deep Learning

Dalam sub bagian ini, memperjelas beragam konsep *deep learning* yang berkaitan erat dengan *review* pada penelitian. Bentuk teknik yang digunakan seperti *Multilayer Perceptron* (MLP) yang merupakan jaringan saraf umpan balik dengan lebih dari satu lapisan tersembunyi antara layer input dan layer output, dimana perceptron dapat menggunakan fungsi aktivasi sembarang dan tidak perlu harus menggunakan klasifikasi biner. *Auto Encoder* (AE) merupakan *unsupervised learning method* yang mencoba merekonstruksi masukan data di lapisan keluaran secara umum, lapisan *bottleneck* (lapisan paling tengah) digunakan sebagai representasi fitur menonjol dari data masukan. Ada banyak varian dari *autoencoders* seperti *denoising autoencoder*,



*autoencoder denoising marjinal, sparse autoencoder, autoencoder kontraktif dan variasional autoencoder (VAE )* [13, 14]. *Convulation Neura Network (CNN)* adalah jenis jaringan khusus neural network dengan lapisan konvolusi dan operasi penyatuan. Hal ini mampu menangkap fitur global dan lokal dan secara signifikan mampu meningkatkan efisiensi dan akurasi. *Recurrent Neural Network (RNN)* merupakan suatu model data yang cocok untuk data *sequential*, cocok untuk pemodelan data *sequential*, memiliki loop dan memory di RNN yang digunakan untuk mengingat perhitungan sebelumnya. Jenis varian dari RNN seperti jaringan *Long Short Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)* sering digunakan dalam praktik untuk mengatasi masalah gradien, *Deep Semantic Similarity Model (DSSM)* adalah sebuah *metode deep neural network* untuk *learning semantic* yang merepresentasi entitas pada ruang *semantic* lanjut dan melakukan perhitungan *semantic similarity*. *Restricted Boltzmann Machine (RBM)* merupakan dua lapisan neural network yang terdiri atas *visible layer* dan *hidden layer*. *Restricted* dimaksud adalah tidak adanya intra layer komunikasi diantara *visible* dan *hidden layer* tersebut.

### Perbandingan Metode Deep Learning Dalam Aplikasi Berbagai Domain

Dalam keseluruhan domain yang dipelajari dalam penelitian ini, *Deep Learning* menunjukkan kinerja yang lebih baik daripada pendekatan yang ada yang tergambar dalam *state of the art* pada penelitian sebelumnya untuk setiap domain. Teknik *Deep Learning* memungkinkan model untuk secara otomatis mempelajari fitur bagi pengguna dan *item* dari sumber daya yang berbeda. Fitur ini digeneralisasi dengan baik dan dapat digunakan secara efektif untuk meningkatkan kualitas rekomendasi. Secara keseluruhan, karena keterbatasan pendekatan rekomendasi tradisional, potensi informasi konten belum sepenuhnya dieksploitasi. Dengan bantuan keuntungan dari *Deep Learning* dalam pemodelan berbagai tipe data, sistem rekomendasi dengan *Deep Learning* dapat lebih memahami apa yang dibutuhkan

pelanggan dan selanjutnya mampu meningkatkan kualitas rekomendasi. Perbandingan aplikasi Deep Learning di berbagai domain dapat dilihat pada tabel 1.

**Tabel 1.** Perbandingan Aplikasi dengan metode deep learning pada berbagai domain

No	Domain	Arsitektur	Kelebihan	Kelemahan
1	Image	Dual-net and Comparative Deep Learning (CDL)	Terdapat dua 3 sub-jaringan, bagian atas dan bawah adalah CNN, bagian tengah CNN yang digunakan sebagai informasi pengguna dengan memiliki 1 layer konvolusi, 3 layer max pooling, dan 3 layer fully connected.	Kelemahan Dual-net dan CDL menggunakan pendekatan yang ada pada image.
2	Speech Recognition	Deep Speech	RNN menggunakan GPU	Deep Speech mampu menangani lingkungan yang bising dan banyak digunakan, dan ini lebih baik daripada sistem komersial deep speech.
3	Text Mining	DeepCoNN	Struktur CNN yang terdiri dari dua jaringan saraf paralel	DeepCoNN memiliki 1.7x secara keseluruhan pada tipe dataset yaitu Yelp, News dan Amazon. DeepCoNN dapat secara efektif menggunakan model sparse, Alex-Net secara signifikan lebih dibandingkan dengan Model FeatureNet (MF).
4		Ada-CNN	Ada-CNN menggunakan struktur jaringan yang sama untuk jaringan pengguna dan item. Arsitektur berdasarkan model yang menggunakan representasi dari seluruh kata kunci dan model CNN yang memiliki dua output untuk representasi kata kunci. Arsitektur ini menggunakan model layer CNN dan layer fully connected.	
5	Time-series data prediction	Deep Kalman Network (DKN)	DKN menggunakan 1 layer dengan Particle Swarm Optimization (PSO) untuk mengoptimalkan parameter pembelajaran.	Akumulasi prediksi DKN lebih tinggi bisa dibandingkan dengan konvensional MLP dan ARIMA, tetapi belum mampu mengatasi data yang CARS yaitu model Kalman smoother dan Model Ensemble.

### PENUTUP

Dalam artikel ini, kami memberikan ulasan tentang penelitian yang dilakukan hingga saat ini mengenai sistem rekomendasi menggunakan metode *deep learning*. Penggunaan metode *deep learning* pada Image menggunakan Dual-net dan Comparative Deep Learning (CDL) yang terdiri dari 3 Subjaringan, bagian atas dan bawah adalah CNN, bagian tengah CNN yang digunakan sebagai informasi pengguna. Arsitektur ini memiliki 5 layer konvolusi, 3 layer *max pooling*, 3 lapisan *fully connected* mampu mengungguli pendekatan yang ada. *Deep Speech* dengan menggunakan RNN dengan GPU mampu menangani lingkungan yang bising dan banyak digunakan dan lebih baik daripada sistem komersial *deep speech*. Pendekatan dalam penambangan teks menunjukkan bahwa CNN dapat digunakan untuk meningkatkan kinerja pada sistem rekomendasi yang melakukan pemrosesan tinjauan teks menggunakan arsitektur

*DeepCoNN* dan *Attn + CNN*. Prediksi data time series dapat ditingkatkan dengan menggunakan arsitektur *Deep Belief Network* (DBN) yang memberikan akurasi prediksi lebih tinggi daripada algoritma konvensional. *Metode deep learning* dan sistem rekomendasi menjadi topik penelitian yang hangat dalam beberapa dekade terakhir.

Penelitian yang dapat dikembangkan dalam penelitian selanjutnya adalah menggabungkan metode *deep learning*, terutama pada model CNN yang merepresentasikan tinjauan teks dengan mengekstraksi kredibilitas profil reviewer, yang dapat mendefinisikan pengukuran *expertise*, *trustworthiness* dan *Co-orientation*. Oleh karena itu, sistem rekomendasi sebaiknya tidak hanya melakukan pemodelan historis yang akurat, tetapi lebih dari pengalaman holistik terhadap pengguna.

#### DAFTAR PUSTAKA

- James Davidson, Benjamin Liebald, Junning Liu, Palash Nandy, Taylor Van Vleet, Ullas Gargi, Sujoy Gupta, Yu He, Mike Lambert, Blake Livingston, and Dasarathi Sampath. "The YouTube Video Recommendation System", In Proceedings of the Fourth ACM Conference on Recommender Systems (RecSys '10). ACM, New York, NY, USA, pp. 293–296, 2010.
- Heng-Tze Cheng, Levent Koc, Jeremiah Harmsen, Tal Shaked, Tushar Chandra, Hrishi Aradhye, Glen Anderson, Greg Corrado, Wei Chai, Mustafa Ispir, et al., "Wide & deep learning for recommender systems", In Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. ACM, pp. 7–10, 2016.
- Paul Covington, Jay Adams, and Emre Sargin, "Deep neural networks for youtube recommendations", In Proceedings of the 10th ACM Conference on Recommender Systems, ACM, pp. 191–198, 2016.
- Shumpei Okura, Yukihiro Tagami, Shingo Ono, and Akira Tajima, "Embedding-based News Recommendation for Millions of Users", In Proceedings of the 23th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, 2017.
- Scafer, J.B, Konsta, J.A. and Riedl, J, "Item-Base Collaborative Filtering Recommender Algorithm", 2016.
- J. Wang, J. Yang, K. Yu, F. Lv, T. Huang, and Y. Gong, "Locality-Constrained Linear Coding for Image Classification", In CVPR, pp 3360–3367, 2010.
- H. Lee, P. Pham, Y. Largman, and A. Y. Ng, "Unsupervised Feature Learning for Audio Classification Using Convolutional Deep Belief Networks", In Advances in Neural Information Processing Systems, pp 1096–1104, 2009.
- G. Ling, M. R. Lyu, and I. King, "Ratings Meet Reviews, A Combined Approach to Recommend", In Proceedings of the 8th ACM Conference on Recommender systems, ACM, pp105–112, 2014.
- H. Wang, Y. Lu, and C. Zhai, "Latent Aspect Rating Analysis on Review Text data: a Rating Regression Approach", In Proceedings of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM, pp 783–792, 2010.
- [10] Lei zheng, [Noroozi V](#), [Philip S. Yu](#), Deep Model to Learn Item Properties and User Behavior Jointly from Review Text, Department of computer science, 2017
- Sungyong Seo, Jing Huang, Hao Yang dan Yan Liu, Representation Learning of Users and items for Review rating Prediction using Attention-based Convolutional Neural Network. 3<sup>rd</sup> international workshop on machine learning methods for recommender System, 2017
- Kuremoto T, Kimura S and Kobayashi K, "Time Series Forecasting Using A Deep Belief Network with Restricted Boltzmann Machines", Neurocomputing 137, pp. 47-56, 2014.

- Minmin Chen, Zhixiang Xu, Kilian  
Weinberger, and Fei Sha,  
“Marginalized Denoising  
Autoencoders for Domain  
Adaptation”, *arXiv preprint  
arXiv:1206.4683*, 2012.
- Ian Goodfellow, Yoshua Bengio, and  
Aaron Courville, “Deep Learning”,  
MIT Press.  
<http://www.deeplearningbook.org>,  
2016



